# TEXT RETRIEVAL DEVICE, EFFECTIVE WORD FREQUENCY PREPARATION DEVICE, TEXT RETRIEVAL METHOD, EFFECTIVE WORD FREQUENCY PREPARATION METHOD AND RECORDING MEDIUM

Patent number: JP2000112990 (A)
Publication date: 2000-04-21

Inventor(s): OTANI NORIKO; ITO SHIRO; UEDA TAKANARI; IKEDA YUJI ÷

Applicant(s): CANON KK +

Classification:

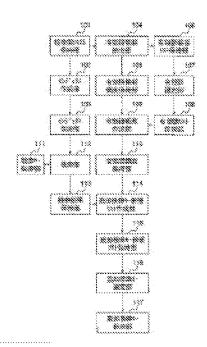
- international: G06F17/30; G06F17/30; (IPC1-7); G06F17/30

- european:

Application number: JP19980300316 19981008 Priority number(s): JP19980300316 19981008

#### Abstract of JP 2000112990 (A)

PROBLEM TO BE SOLVED: To provide a text retrieval device and a text retrieval method which can easily re-retrieval matching a retrieval object document and a retrieval result document. SOLUTION: A block 104 extracts an effective word which becomes a candidate for an additional retrieval key from a retrieval object document, counts an appearance frequency in each document and prepares an effective word candidate list. Then, a block 107 refers to the effective word candidate list and prepares an effective word list. Furthermore, a block 109 deletes a word which is not an effective word from a document frequency of the effective word candidate held in a block 105 and prepares the document frequency of the effective word. A block 114 prepares an additional retrieval key candidate list from the one which corresponds to a document of the retrieval result out of the document frequency of the held effective word. A block 116 refers to the additional retrieval key candidate list and calculates an evaluation value for each additional retrieval key candidate. Then, the one whose-obtained evaluation value is high is presented as an additional retrieval



Data supplied from the espacenet database - Worldwide

#### (19) [] 本国特許庁(JP)

### (12) 公開特許公報(A)

(II)特許出願公開番号 特開2000-112990

(P2000-112990A)

(43)公開日 平成12年4月21日(2000.4.21)

(51) Int.CL 7 G 0 6 F 17/30 囊別記号

FΙ

テーマコート (参考)

G 0 6 F 15/401

310A 5B075

15/403

340B

#### 審査請求 未請求 請求項の数12 FD (全 13 頁)

(21)出顯番号

(22)出額日

特願平10-300316

平成10年10月8日(1998, 10.8)

(71)出願人 000001007

キヤノン株式会社

東京都大田区下丸子3丁目30番2号

(72)発明者 大谷 紀子

東京都大田区下丸子3丁目30番2号 キヤ

ノン株式会社内

(72)発明者 伊藤 史朗

東京都大田区下丸子3丁目30番2号 キヤ

ノン株式会社内

(74)代理人 100081880

弁理士 渡部 敏彦

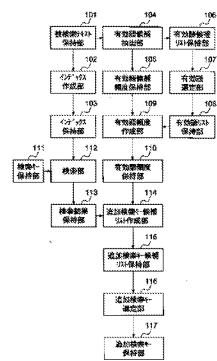
最終買に続く

## (54)【発明の名称】 テキスト検索装置、有効語頻度作成装置、テキスト検索方法、及び有効語頻度作成方法並びに記録媒体

#### (57)【婴約】

【課題】 検索対象文書と検索結果文書に適合した再検索が容易に行なえるテキスト検索装置及びテキスト検索 方法を提供する。

【解決手段】 ブロック104は、検索対象文書から追加検索キーの候補となる有効語を抽出し、各文書における出現頻度をカウントして有効語候補リストを作成する。そして、ブロック107は、有効語候補リストを参照して有効語リストを作成する。さらに、ブロック109は、ブロック105に保持された有効語媒補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する。ブロック114は、保持されている有効語の文書別頻度のうち、検索結果の文書に相当するものから、追加検索キー候補リストを参照して、各追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する。そして、求めた評価値が高いものを追加検案キーとして提示する。



#### 【特許請求の範囲】

【請求項1】 被検索テキストに対してインデックスを 作成するインデックス作成手段と、

前記被検索テキストから有効器候補を抽出し、各文書に おける出現頻度をカウントして有効語候補リストを作成 する有効語候補油出手段と、

前記有効語候補抽出手段により抽出された有効語候補の 出現頻度を文書別に保持する有効語候補頻度保持手段 と、

前記有効語候補ジストを参照して、各有効語候補の評価 10 値を算出し、評価値の高い有効語候補を有効語として、 有効語リストを作成する有効語選定手段と、

前記有効語リストを参照し、前記有効語候補頻度保持手段に保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語頻度作成手段と、

前記インデックスにより。検索文字列に一致する文字列 を検索する検索手段と。

前記有効語類度保持手段に保持された有効語の文書別類 度のうち、前記検索手段の検索結果の文書に相当するも 20 のから、追加検索キー候補リストを作成する追加検索キ 一候補リスト作成手段と、

前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー選定手段と、

前記追加検索キー選定手段により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示手段とを備えたことを特徴とするテキスト検索装置。

【請求項2】 被検索テキストを保持する被検索テキスト保持手段と、

前記被検索テキスト保持手段に保持されている被検索テ 30 キストに対して、インデックスを作成するインデックス 作成手段と、

前記インデックス作成手段で作成したインデックスを保持するインデックス保持手段と、

前記被検索テキスト保持手段に保持されている被検索テキストから有効語候補を抽出し、各文書における出現頻度をカウントして有効語候補リストを作成する有効語候 補抽出手段と、

前記有効語候補抽出手段により抽出された有効語候補の 出現頻度を文書別に保持する有効語候補頻度保持手段 と、

前記有効語候補抽出手段により作成された有効語候補リストを保持する有効語候補リスト保持手段と、

前記有効語候補リスト保持手段に保持された有効語候補 リストを参照して、各有効語候補の評価値を算出し、評価値の高い有効語候補を有効語として有効語リストを作 成する有効語選定手段と、

前記有効語選定手段により作成された有効語リストを保 持する有効語リスト保持手段と、

前記有額語リスト保持手段に保持された有効語リストを 50 一候補の評価値を算出する追加検索キー選定手段と、

参照し、上記有効語候補頻度保持手段に保持された有効 語候補の文書別頻度から有効語でない語を削除して、有 効語の文書別頻度を作成する有効語頻度作成手段と、

前記有効語頻度作成手段により作成された有効語の文書 別頻度を保持する有効語頻度保持手段と、

検索を行なう文字列を保持する検索キー保持手段と、 前記インデックス保持手段に保持されているインデック

前記インテックス保持手段に保持されているインテックスを用いて、前記検索キー保持手段に保持されている検索文字列に一致する文字列を検索する検索手段と、

) 前記検案手段により検案された検案結果を保持する検案 結果保持手段と

前記有効語類度保持手段に保持された有効語の文書別類 度のうち、前記検索結果保持手段に保持された検索結果 の文書に相当するものから、追加検索キー候補リストを 作成する追加検索キー候補リスト作成手段と、

前記追加検索キー候補リスト作成手段により作成された 追加検索キー候補リストを保持する追加検索キー候補リ スト保持手段と、

前記追加検索キー候補リスト保持手段に保持された追加 ・ 検索キー候補リストを参照して、各追加検索キー候補の 評価値を算出する追加検索キー選定手段と、

前記追加検索キー選定手段により求めた評価値が高いものを追加検索キーとして保持する追加検索キー保持手段 と

追加検索キー保持手段に保持された追加検索キーを出力 する追加検索キー提示手段とを備えたことを特徴とする テキスト検索装置。

【請求項3】 テキストから有効語候補を抽出し、各文 書における出現頻度をカウントして有効語候補リストを 作成する有効語候補抽出手段と、

前記有効候補抽出手段により抽出された有効語候補の出 現類度を文書別に保持する有効語候補頻度保持手段と、 前記有効語候補リストを参照して各有効語候補の評価値 を算出し、評価値の高い有効語候補を有効語として有効 語リストを作成する有効語機定手段と、

前記有効語リストを参照し、前記有効語候補類度保持手段に保持された有効語候補の文書別類度から有効語でない語を削除して、有効語の文書別類度を作成する有効語類度作成手段とを備えたことを特徴とする有効語類度作 40 成装置。

【請求項4】 被検索テキストに対してインデックスを 作成するインデックス作成手段と、

前記インデックスにより、検索文字列に一致する文字列 を検索する検索手段と、

請求項3記載の有効語類度作成装置によって作成された 有効語の文書別類度のうち、前記検索手段の検索結果の 文書に相当するものから、追加検索キー候補リストを作 成する追加検索キー候補リスト作成手段と、

前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー選定手段と

9/8/2009, EAST Version: 2.4.1.1

前記追加検索キー選定手段により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示手段とを備えたことを特徴とするテキスト検索装置。

【請求項5】 被検索テキストに対してインデックスを 作成するインデックス作成行程と、

前記級検索テキストから有効語候補を抽出し、各文器に おける出現頻度をカウントして有効語候補リストを作成 する有効語候補油出行程と。

前記有効語候補抽出行程により抽出された有効語候補の 出現頻度を文書別に保持する有効語候補頻度保持行程 と、

前記有効語候補リストを参照して、各有効語候補の評価 値を算出し、評価値の高い有効語候補を有効語として、 有効語リストを作成する有効語選定行程と、

前記有効語リストを参照し、前記有効語候補頻度保持行程で保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語頻度作成行程と、

前記インデックスにより、検索文字列に一致する文字列 を検索する検索行程と、

前記有効語頻度保持行程で保持された有効語の文書別頻度のうち、前記検索行程の検索結果の文書に相当するものから、追加検索キー候補リストを作成する追加検索キー候補リスト作成行程と、

前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を無出する追加検索キー選定行程と、

前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示行程とを実行することを特徴とするテキスト検索方法。

【請求項6】 被検索テキストを保持する被検索テキス 30 ト保持行程と

前記被検索テキスト保持行程で保持されている被検索テキストに対して、インデックスを作成するインデックス 作成行程と、

前記インデックス作成行程で作成したインデックスを保 持するインデックス保持行程と

前記被検索テキスト保持行程で保持されている被検索テキストから有効語候補を抽出し、各文書における出現類度をカウントして有効語候補リストを作成する有効語候補組出行程と、

前記有効語候補抽出行程により抽出された有効語候補の 出現頻度を文書別に保持する有効語候補頻度保持行程 と、

前記有効語候補抽出行程により作或された有効語候補リストを保持する有効語候補リスト保持行程と、

前記有効語候補リスト保持行程で保持された有効語候補 リストを参照して、各有効語候補の評価値を算出し、評 価値の高い有効語候補を有効語として有効語リストを作 成する有効語選定行程と、

前記有劾語選定行程により作成された有効語リストを保 50 成する追加検索キー候補リスト作成行程と、

持する有効語リスト保持行程と、

前記有効語リスト保持行程で保持された有効語リストを 参照し、上記有効語候補頻度保持行程で保持された有効 語候補の文書別頻度から有効語でない語を削除して、有 効語の文書別頻度を作成する有効語頻度作成行程と、

前記有効語頻度作成行程により作成された有効語の文書 別頻度を保持する有効語頻度保持行程と、

検索を行なう文字列を保持する検索キー保持行程と、

前記インデックス保持行程で保持されているインデック 10 スを用いて、前記検索キ…保持行程で保持されている検 案文字列に一致する文字列を検索する検索行程と、

前記検索行程により検索された検索結果を保持する検索 結果保持行程と、

前記有効語頻度保持行程で保持された有効語の文書別類 度のうち、前記検索結果保持行程で保持された検索結果 の文書に相当するものから、追加検索キー候補リストを 作成する追加検索キー候補リスト作成行程と.

前記追加検索キー候補リスト作成行程により作成された 追加検索キー候補リストを保持する追加検索キー候補リ 20 スト保持行程と、

前記追加検索キー候補リスト保持行程で保持された追加 検索キー候補リストを参照して、各追加検索キー候補の 評価値を算出する追加検索キー選定行程と、

前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして保持する追加検索キー保持行程 レ

追加検索キー保持行程で保持された追加検索キーを出力 する追加検索キー提示行程とを実行することを特徴とす るテキスト検索方法。

30 【請求項7】 テキストから有効語候補を抽出し、各文 書における出現頻度をカウントして有効語候補リストを 作成する有効語候補抽出行程と、

前記有効候補抽出行程により抽出された有効語候補の出 現頻度を文書別に保持する有効語候補頻度保持行程と、 前記有効語候補リストを参照して、各有効語候補の評価 値を算出し、評価値の高い有効語候補を有効語として、 有効語リストを作成する有効語鑑定行程と、

前記有効語リストを参照し、前記有効語候補頻度保持行程で保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語

ひ い語で削除して、有効語のX番別類及で作成する有効語頻度 頻度作成行程とを実行することを特徴とする有効語頻度 作成方法。

【請求項8】 被検索テキストに対してインデックスを 作成するインデックス作成行程と、

前記インデックスにより、検索文字列に一致する文字列 を検索する検索行程と、

請求項7記載の有効語頻度作成方法によって作成された 有効語の文書別頻度のうち、前記検索行程の検索結果の 文書に相当するものから、追加検索キー候補リストを作

A WEST OF THE WATER TO SEE THE SECTION OF THE PARTY OF TH

前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー選定行程と、

前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示行程とを実行することを特徴とするテキスト検索方法。

【蕎求項9】 被検索テキストに対してインデックスを 作成するインデックス作成行程と、

前記被検索テキストから有効語候補を抽出し、各文器に おける出現頻度をカウントして有効語候補リストを作成 する有効語候補抽出行程と、

前記有効語候補抽出行程により抽出された有効語候補の 出現頻度を文書別に保持する有効語候補頻度保持行程 と、

前記有効語候補リストを参照して、各有効語候補の評価 値を算出し、評価値の高い有効語候補を有効語として、 有効語リストを作成する有効語選定行程と、

前記有効語リストを参照し、前記有効語候補頻度保持行程で保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語頻度作成行程と、

前記インデックスにより、検索文字列に一致する文字列 を検索する検索行程と、

前記有効語頻度保持行程で保持された有効語の文書別頻度のうち、前記検索行程の検索結果の文書に相当するものから、追加検案キー候補リストを作成する追加検案キー候補リスト作成行程と、

前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー選定行程と、

前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示行程 30 とを含むプログラムを格納したことを特徴とするコンピュータ読み取り可能な記録媒体。

【請求項10】 被検索テキストを保持する被検索テキ スト保持行程と、

前記被検索テキスト保持行程で保持されている被検索テキストに対して、インデックスを作成するインデックス 作成行程と、

前記インデックス作成行程で作成したインデックスを保 持するインデックス保持行程と、

前記被検索テキスト保持行程で保持されている被検索テキストから有効語候補を抽出し、各文書における出現頻度をカウントして有効語候補リストを作成する有効語候補地出行程と、

前記有効語候補抽出行程により抽出された有効語候補の 出現頻度を文書別に保持する有効語候補頻度保持行程 と、

前記有効語候補抽出行程により作成された有効語候補リストを保持する有効語候補リスト保持行程と、

前記有効語候補リスト保持行程で保持された有効語候補 前記インデックスにより リストを参照して、各有効語候補の評価値を算出し、評 切 を検索する検索行程と、

価値の高い有効語候補を有効語として有効語リストを作成する有効語選定行程と、

前記有効語選定行程により作成された有効語リストを保 持する有効語リスト保持行程と、

前記有効語リスト保持行程で保持された有効語リストを 参照し、上記有効語候補頻度保持行程で保持された有効 語候補の文書別頻度から有効語でない語を削除して、有 効語の文書別頻度を作成する有効語頻度作成行程と、

前記有効語頻度作成行程により作成された有効語の文書 10 別頻度を保持する有効語頻度保持行程と、

検索を行なう文字列を保持する検索キー保持行程と、 前記インデックス保持行程で保持されているインデック スを用いて、前記検索キー保持行程で保持されている検 案文字列に一致する文字列を検索する検索行程と、

前記検索行程により検索された検索結果を保持する検索 結果保持行程と、

前記有効語頻度保持行程で保持された有効語の文書別頻 度のうち、前記検索結果保持行程で保持された検索結果 の文書に相当するものから、追加検索キー候補リストを 作成する追加検索キー候補リスト作成行程と、

前記追加検索キー候補リスト作成行程により作成された 追加検索キー候補リストを保持する追加検索キー候補リ スト保持行程と、

前記追加検索キー候補リスト保持行程で保持された追加 検索キー候補リストを参照して、各追加検索キー候補の 評価値を復出する追加検索キー選定行程と、

前配追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして保持する追加検索キー保持行程 と

30 追加検索キー保持行程で保持された追加検索キーを出力する追加検索キー提示行程とを含むプログラムを格納したことを特徴とするコンピュータ読み取り可能な記録媒体。

【請求項11】 テキストから有効語候補を抽出し、各 文書における出現頻度をカウントして有効語候補リスト を作成する有効語候補抽出行程と、

前記有効候補抽出行程により抽出された有効語候補の出 現類度を文書別に保持する有効語候補類度保持行程と、 前記有効語候補リストを参照して、各有効語候補の評価

値を算出し、評価値の高い有効語候補を有効語として、 有効語リストを作成する有効語選定行程と、

前記有効語リストを参照し、前記有効語候補頻度保持行程で保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語頻度作成行程とを含むプログラムを格納したことを特徴とするコンピューク読み取り可能な記録媒体。

【請求項12】 被検索テキストに対してインデックスを作成するインデックス作成行程と、

前記インデックスにより。検索文字列に一致する文字列 ・ を検索する検索行程と。

請求項11記載の記録媒体中の有効語頻度作成行程によって作成された有効語の文書別頻度のうち、前記検索行程の検索結果の文書に相当するものから、過加検索キー候補リスト作成行程と、

前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を録出する追加検索キー選定行程と、 前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示行程 とを含むプログラムを格納したことを特徴とするコンピー10 ュータ読み取り可能な記録媒体。

#### 【発明の詳細な説明】

#### [0001]

【発明の屬する技術分野】本発明は、検索対象文書から 検索キーに対応した文書を提示するテキスト検索装置及 びテキスト検索方法と、テキストにおける有効語の文書 別類度を作成する有効語類度作成装置及び有効語類度作 成方法並びに記録媒体に関する。

#### [0002]

【従来の技術】一般に、テキスト検索装置では、検索対 20 象文書から与えられた検索キーを含む文書を検索結果と して提示する。

#### [0003]

【発明が解決しようとする課題】しかしながら、上記従来の装置では、大量に得られた検索結果を絞り込む場合や、関連する情報をさらに集めたい場合には、適切な検索キーを追加して検索をやり直さなくてはならないという問題があった。

【0004】そこで、検索キーに関連する語を追加検索キーとして提示し、再検索を容易にすることが考えられ 30 る。しかし、あらかじめ用意された辞書から検索キーの関連語を選択するのでは、辞書にない検索キーに対応できなかったり、関連語を追加しても結果があまり変わらなかったりする。また、関連語は検索対象文書によっても異なり、検索対象文書に合わせて追加検索キーの候補を決める必要がある。すなわち、再検索は、検索対象文書と検索結果文書に適合して行う必要があるが、従来ではこれを容易に行う手法がなかった。

【0005】本発明は上記従来の問題点に鑑み、検索対象文書と検索結果文書に適合した再検索が容易に行なえるテキスト検索装置及びテキスト検索方法を提供することを目的とする。また、テキストにおける有効語の文書別類度を簡易かつ的確に作成する有効語頻度作成装置及び有効語頻度作成方法並びに記録媒体を提供することを目的とする。

#### [0006]

カウントして有効語候補リストを作成する有効語候補抽 出手段と、前記有効語候補抽出手段により抽出された有 効語候補の出現頻度を文書別に保持する有効語候補頻度 保持手段と、前記有効語候補リストを参照して、各有効 語候補の評価値を算出し、評価値の高い有効語候補を有 効語として、有効語リストを作成する有効語選定手段 と、前記有効語リストを参照し、前記有効語候補頻度保 持手段に保持された有効語候補の文書別頻度から有効語 でない語を削除して、有効語の文書別頻度を作成する有 **効語頻度作成手段と、前記インデックスにより、検案文** 字列に一致する文字列を検索する検案手段と、前記有効 語頻度保持手段に保持された有効語の文書別頻度のう ち、前記検索手段の検索結果の文書に相当するものか ら、追加検索キー候補リストを作成する追加検索キー候 補リスト作成手段と、前記追加検索キー候補リストを参 照して、各追加検索キー候補の評価値を算出する追加検 索キー選定手段と、前記追加検索キー選定手段により求 めた評価値が高いものを追加検索キーとして出力する追 加検索キー提示手段とを備えたものである。

8

【0007】第2の発明では、被検索テキストを保持す る彼検索テキスト保持手段と、前記被検索テキスト保持 手段に保持されている被検索テキストに対して、インデ ックスを作成するインデックス作成手段と、前記インデ ックス作成手段で作成したインデックスを保持するイン デックス保持手段と、前記被検索テキスト保持手段に保 持されている被検索テキストから有効語候補を抽出し、 各文書における出現頻度をカウントして有効語候補リス トを作成する有効語候補抽出手段と。前記有効語候補抽 出手段により抽出された有効語候補の出現頻度を文書別 に保持する有効語候補頻度保持手段と、前記有効語候補 抽出手段により作成された有効語候補リストを保持する 有効語候補リスト保持手段と、前記有効語候補リスト保 持手段に保持された有効語候補リストを参照して。各有 効語候補の評価値を算出し、評価値の高い有効語候補を 有効語として有効語リストを作成する有効語選定手段 と、前記有効語磁定手段により作成された有効語リスト を保持する有効語リスト保持手段と、前記有効語リスト 保持手段に保持された有効語リストを参照し、上記有効 語候補頻度保持手段に保持された有効語候補の文書別類 度から有効語でない語を削除して、有効語の文書別頻度 を作成する有効語頻度作成手段と、前記有効語頻度作成 手段により作成された有効語の文書別頻度を保持する有 効語頻度保持手段と、検索を行なう文字列を保持する検 索キー保持手段と、前記インデックス保持手段に保持さ れているインデックスを用いて、前記検索キー保持手段 に保持されている検索文字列に一致する文字列を検索す る検索手段と、前記検索手段により検索された検索結果 を保持する検索結果保持手段と、前記有効語頻度保持手 段に保持された有効語の文書別頻度のうち、前記検索結 から、適加検索キー候補リストを作成する追加検索キー 候補リスト作成手段と、前記追加検索キー候補リストを保持 或手段により作成された追加検索キー候補リストを保持 する追加検索キー候補リスト保持手段と、前記追加検索 キー候補リスト保持手段に保持された追加検索キー候補 リストを参照して、各追加検索キー候補の評価値を算出 する追加検索キー選定手段と、前記追加検索キー選定手 段により求めた評価値が高いものを追加検索キーとして 保持する追加検索キー保持手段と、追加検索キー保持手 段に保持された追加検索キーを出力する追加検索キー提 10 示手段とを備えたものである。

【0008】第3の発明では、テキストから有効語候補を抽出し、各文書における出現頻度をカウントして有効語候補リストを作成する有効語候補抽出手段と、前記有効候補抽出手段により抽出された有効語候補の出現頻度を文書別に保持する有効語候補頻度保持手段と、前記有効語候補の高い有効語候補を有効語として有効語リストを作成する有効語選定手段と、前記有効語リストを参照し、前記有効語候補頻度保持手段に保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度から有効語質ない語を削除して、有効語の文書別頻度を作成する有効語頻度作成手段とを備えたものである。

【0009】第4の発明では、被検索テキストに対してインデックスを作成するインデックス作成手段と、前記インデックスにより、検索文字列に一致する文字列を検索する検索手段と、第3の発明の有効語頻度作成装置によって作成された有効語の文書別類度のうち、前記検索手段の検索結果の文書に相当するものから、追加検索キー候補リストを作成する追加検索キー候補リスト作成手段と、前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー選定手段と、前記追加検索キー選定手段により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示手段とを備えたものである。

【0010】第5の発明では、被検索テキストに対してインデックスを作成するインデックス作成行程と、前記被検索テキストから有効語候補を抽出し、各文書における出現頻度をカウントして有効語候補りストを作成する有効語候補抽出行程により抽出された有效語候補の出現頻度を文書別に保持する有効語候補頻度保持行程と、前記有効語候補リストを参照して、各有効語候補の評価値を算出し、評価値の高い有効語候補を有効語として、有効語リストを作成する有効語として、有効語リストを作成する有効語機補頻度保持行程で保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語頻変作成行程と、前記インデックスにより、検索文字列に一致する文字列を検索する検索行程

10

別類度のうち、前記検索行程の検索結果の文書に相当す るものから、追加検索キー候補リストを作成する追加検 索キー候補リスト作成行程と、前記追加検索キー候補リ ストを参照して、各追加検索キー候補の評価値を算出す る追加検索キー選定行程と、前記追加検索キー選定行程 により求めた評価値が高いものを追加検索キーとして出 力する追加検索キー提示行程とを実行するものである。 【0011】第6の発明では、被検索テキストを保持す る彼検索テキスト保持行程と、前記被検索テキスト保持 行程で保持されている被検索テキストに対して、インデ ックスを作成するインデックス作成行程と、前記インデ ックス作成行程で作成したインデックスを保持するイン デックス保持行程と、前記被検索テキスト保持行程で保 持されている被検索テキストから有効語候補を抽出し、 各文書における出現頻度をカウントして有効語候補リス トを作成する有効語候補油出行程と、前記有効語候補抽 出行程により抽出された有効語候補の出現頻度を文書別 に保持する有効語候補頻度保持行程と、前記有効語候補 抽出行程により作成された有効語候補リストを保持する 有効語候補リスト保持行程と、前記有効語候補リスト保 持行程で保持された有効語候補リストを参照して、各有 効語候補の評価値を算出し、評価値の高い有効語候補を 有効語として有効語リストを作成する有効語選定行程 と、前記有効語選定行程により作成された有効語リスト を保持する有効語リスト保持行程と、前記有効語リスト 保持行程で保持された有効語リストを参照し、上記有効 語候補頻度保持行程で保持された有効語候補の文書別類 度から有効語でない語を削除して、有効語の文書別頻度 を作成する有効語頻度作成行程と、前記有効語頻度作成 行程により作成された有効語の文書別頻度を保持する有 効語類度保持行程と、検索を行なう文字列を保持する検 索キー保持行程と、前記インデックス保持行程で保持さ れているインデックスを用いて、前記検索キー保持行程 で保持されている検索文字列に一致する文字列を検索す る検索行程と、前記検索行程により検索された検索結果 を保持する検索結果保持行程と、前記有効語頻度保持行 程で保持された有効語の文書別頻度のうち、前記検索結 果保持行程で保持された検索結果の文書に相当するもの から、追加検索キー候補リストを作成する追加検索キー 候補リスト作成行程と、前記追加検索キー候補リスト作 或行程により作成された追加検索キー候補リストを保持 する追加検索キ…候補リスト保持行程と、前記追加検索 キー候補リスト保持行程で保持された追加検索キー候補 リストを参照して、各追加検索キー候補の評価値を算出 する追加検索キー選定行程と、前記追加検索キー選定行 程により求めた評価値が高いものを追加検索キーとして 保持する追加検索キー保持行程と、追加検索キー保持行 程で保持された追加検索キーを出力する追加検索キー提 示行程とを実行するものである。

と、前記有効語頻度保持行程で保持された有効語の文書 50 【0012】第7の発明では、テキストから有効語候補

を抽出し、各文書における出現類度をカウントして有効 語候補リストを作成する有効語候補抽出行程と、前記有 効候補抽出行程により抽出された有効語候補の出現類度 を文書別に保持する有効語候補類度保持行程と、前記有 効語候補リストを参照して、各有効語候補の評価値を算 出し、評価値の高い有効語候補を有効語として、有効語 リストを作成する有効語選定行程と、前記有効語リスト を参照し、前記有効語候補類度保持行程で保持された有 効語候補の文書別頻度から有効語でない語を削除して、 有効語の文書別頻度を作成する有効語類度作成行程とを 実行するものである。

【0013】第8の発明では、被検索テキストに対してインデックスを作成するインデックス作成行程と、前記インデックスにより、検索文字列に一致する文字列を検索する検索行程と、上記第7の発明の有効語頻度作成方法によって作成された有効語の文書別頻度のうち、前記検索行程の検索結果の文書に相当するものから、追加検索キー候補リストを修成する追加検索キー候補リスト作成行程と、前記追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー選定行程と、前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示行程とを実行するものである。

【0014】第9の発明は、被検索テキストに対してイ ンデックスを作成するインデックス作成行程と、前記被 検索テキストから有効語候補を抽出し、各文書における 出現輝度をカウントして有効語候補リストを作成する有 効語候補抽出行程と、前記有効語候補抽出行程により抽 出された有効語候補の出現頻度を文書別に保持する有効 語候補頻度保持行程と、前記有効語候補リストを参照し て、各有効語候補の評価値を算出し、評価値の高い有効 語候補を有効語として、有効語リストを作成する有効語 選定行程と、前記有効語リストを参照し、前記有効語候 補頻度保持行程で保持された有効語候補の文書別頻度か ら有効語でない語を削除して、有効語の文書別頻度を作 成する有効語頻度作成行程と、前記インデックスによ り、検索文字列に一致する文字列を検索する検索行程 と、前記有効語頻度保持行程で保持された有効語の文書 別頻度のうち、前記検索行程の検索結果の文書に相当す るものから、追加検索キー候補リストを作成する追加検 鱟キー候補リスト作成行程と、前記追加検索キー候補リ ストを参照して、各追加検索キー候補の評価値を算出す る追加検索キー選定行程と、前記追加検索キー選定行程 により求めた評価値が高いものを追加検索キーとして出 力する遺加検索キー提示行程とを含むプログラムを格納 したものである。

【0015】第10の発明は、被検索テキストを保持す を参照し、前記有効語候補類度保持行程 る被検索テキスト保持行程と、前記被検索テキスト保持 効語候補の文書別類度から有効語でない 行程で保持されている被検索テキストに対して、インデ 有効語の文書別類度を作成する有効語数 ックスを作成するインデックス作成行程と、前記インデ 50 含むプログラムを格納したものである。

ックス作成行程で作成したインデックスを保持するイン デックス保持行程と、前記被検索テキスト保持行程で保 持されている被検索テキストから有効語候補を抽出し、 各文書における出現頻度をカウントして有効語候補リス トを作成する有効語候補抽出行程と、前記有效語候補抽 出行程により抽出された有効語候補の出現頻度を文書別 に保持する有効語候補頻度保持行程と、前記有効語候補 抽出行程により作成された有効語候補リストを保持する 有効語候補リスト保持行程と、前記有効語候補リスト保 持行程で保持された有効語候補リストを参照して、各有 **効語候補の評価値を算出し、評価値の高い有効語候補を** 有効語として有効語リストを作成する有効語選定行程 と、前記有効語選定行程により作成された有効語リスト を保持する有効語リスト保持行程と、前記有効語リスト 保持行程で保持された有効語リストを参照し、上記有効 語候補頻度保持行程で保持された有効語候補の文書別類 度から有効語でない語を削除して、有効語の文書別類度 を作成する有効語頻度作成行程と、前記有効語頻度作成 行程により作成された有効語の文書別頻度を保持する有 効語頻度保持行程と、検索を行なう文字列を保持する検 索キー保持行程と、前記インデックス保持行程で保持さ れているインデックスを用いて、前記検索キー保持行程 で保持されている検索文字列に一致する文字列を検索す る検索行程と、前記検索行程により検索された検索結果 を保持する検索結果保持行程と、前記有効語頻度保持行 程で保持された有効語の文書別頻度のうち、前記検索結 果保持行程で保持された検索結果の文書に相当するもの から、追加検索キー候補リストを作成する追加検索キー 候補リスト作成行程と、前記追加検索キー候補リスト作 成行程により作成された追加検索キー候補リストを保持 する遺加検索キー候補リスト保持行程と、前記追加検索 キー候補リスト保持行程で保持された追加検索キー候補 リストを参照して、各追加検索キー候補の評価値を算出 する追加検索キー選定行程と、前記追加検索キー選定行 程により求めた評価値が高いものを追加検索キーとして 保持する追加検索キー保持行程と、追加検索キー保持行 程で保持された追加検索キーを出力する追加検索キー提 ボ行程とを含むプログラムを格納したものである。

12

【0016】第11の発明は、テキストから有効語候補を抽出し、各文書における出現頻度をカウントして有効語候補リストを作成する有効語候補抽出行程と、前記有効候補抽出行程により抽出された有効語候補の出現頻度を文書別に保持する有効語候補頻度保持行程と、前記有効語候補リストを参照して、各有効語候補を有効語として、有効語リストを作成する有効語鑑定行程と、前記有効語リストを参照し、前記有効語候補頻度保持行程で保持された有効語候補の文書別頻度から有効語でない語を削除して、有効語の文書別頻度を作成する有効語頻度作成行程とを全たプログラムを絡納したものである。

1.3

【0017】第12の発明は、被検索テキストに対してインデックスを作成するインデックス作成行程と、前記インデックスにより、検索文字列に一致する文字列を検索する検索行程と、上記第11の発明の記録媒体中の有効語頻度作成行程によって作成された有効語の文書別頻度のうち、前記検索行程の検索結果の文書に相当するものから、追加検索キー候補リストを作成する追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する追加検索キー機定行程と、前記追加検索キー選定行程により求めた評価値が高いものを追加検索キーとして出力する追加検索キー提示行程とを含むプログラムを格納したものである。

#### [0018]

【発明の実施の形態】以下、図面を参照して本発明の実 施の形態を説明する。

【0019】[第1突施形態]図1は、本発明の第1実 施形態のテキスト検索装置の機能構成を示すプロック図 である。

【0020】 開図において、161は、被検索テキスト を保持する被検索テキスト保持部である。102は、被 検索テキスト保持部101に保持されている被検索テキ ストに対して、検索を高速に行なうためのインデックス を作成するインデックス作成部である。103は、イン デックス作成部102で作成したインデックスを保持す るインデックス保持部である。104は、被検索テキス ト保持部101に保持されている被検索テキストから有 効語候補を抽出し、各文書における出現頻度をカウント して有効語候補リストを作成する有効語候補抽出部であ る。有効語候補抽出部104は、被検索テキストを形態 30 素解析し、その結果、名詞と解析された文字列を有効語 候補とする。10万は、有効語候補抽出部104により 抽出された有効語候補の出現頻度を文書別に保持する有 **効語候補類度保持部である。106は、有効語候補抽出** 部104により作成された有効語候補リストを保持する 有効語候補リスト保持部である。有効語候補リストは、 有効語候補ごとに各文書における出現頻度を保持してい る。有効語候補リストの例を図2に示す。

【0021】107は有効語選定部であり、有効語候補 リスト保持部106に保持された有効語候補リストを参 照して各有効語候補の評価値を算出し、評価値の高い有 効語候補を有効語として有効語リストを作成する。有効 語リストの例を図3に示す。評価値は、各有効語候補の 重要度を示す値である。各文書を特徴付ける語が重要な ので、検索対象文書内における各語の局在度を評価値に 反映させるべきであるが、局在度そのものを評価値にす ると、ある文書にたまたま一度出現した語の評価値が高 くなってしまう。そこで、ある程度の出現頻度があり、 かつ局在度の高い語を有効語とするために、出現頻度と 局在度の積を評価値とする。 14

【0022】有効語候補Wiを含む文書数をMとする と、Wiの評価値E(Wi)は次の式により求められる。

【0023】 【数1】

$$E(W_i) = M \cdot (1 + \sum_{j=1}^{M} P_{i,j} \log_M P_{i,j})$$

### $P_{i,j} = rac{\dot{f X} m{b}_j m{\phi}$ における $m{W}_i$ の出現頻度 文書 $m{D}_i$ 中の有効語機補数

108は、有効語選定部107により作成された有効語 リストを保持する有効語リスト保持部である。109は 有効語頻度作成部であり、有効語リスト保持部108に 保持された有効語リストを参照し、有効語候補頻度保持 部105に保持された有効語候補の文書別頻度から有効 語でない語を削除して、有効語の文書別頻度を作成す る。

【0024】110は、有効語頻度作成部109により 作成された有効語の文書別頻度を保持する有効語頻度保 持部である。111は、検索を行なう文字列を保持する 検索キー保持部である。112は検索部であり、インデ ックス保持部103に保持されているインデックスを用 いて、検索キー保持部111に保持されている検索文字 列に一致する文字列を検索する。113は、検索部11 2により検索された検索結果を保持する検索結果保持部 である。

【0025】114は追加検索キー候補リスト作成都であり、有効語頻度保持部110に保持された有効語の文 書別頻度のうち、検索結果保持部113に保持された検 索結果の文書に相当するものから、追加検索キー候補リストを作成する。追加検索キー候補リストは、有効語候 補リストと同様の構造で表現できる。115は、追加検 索キー候補リスト作成部114により作成された追加検 索キー候補リストを保持する追加検索キー候補リスト保 持部である。

【0026】116は追加検索キー選定部であり、追加 検索キー候補リスト保持部115に保持された追加検索 キー候補リストを参照して、各追加検索キー候補の評価 値を算出する。評価値は、各追加検索キー候補の再検索 における有効度を示す値である。検索結果を終り込むた めに再検索を行なうには、検索結果文書において局在度 の高い語が有用と考えられるので、追加検索キー候補W を含む検索結果文書数をMとしたとき、Wiの評価値臣 (Wi)は次の式により求められる。

[0027]

[数2]

$$E(W_i) = M \cdot (1 + \sum_{j=1}^{M} P_{i,j} \log_M P_{i,j})$$

## $P_{i,j} = \frac{$ 文書 $D_j$ 中における $W_i$ の出現頻度 文書 $D_j$ 中の追加検索キー候補数

117は、追加検索キー選定部116により求めた評価値が高いものを追加検索キーとして保持する追加検索キーとして保持する追加検索キー保持部である。

【0028】図4は、本実施形態に係るテキスト検察装 置のハードウェア構成を示す図である。

【0029】 間図において、201は、後述する制御手順を実現するプログラムを保持するROMである。20 2はRAMであり、被検索テキスト保持部101、有効 語候補頻度保持部105、有効語候補リスト保持部10 6. 有効語リスト保持部108、検索キー保持部11 1、検索結果保持部113、追加検索キー候補リスト保 特部115、及び追加検索キー保持部117と、上記プログラムの動作に必要な記憶領域とを提供する。

【0030】203は、ROM201に保持されている プログラムに従って処理を行なう中央処理装置である。 204はディスク装置であり、インデックス保持部10 3、有効語頻度保持部110を実現する。205はバス であり、上記の各構成を接続し、各構成間におけるデータの授受を可能とする。

【0031】次に、本装置の動作を説明する。

【0032】本実施形態の処理は、インデックス作成フェーズと検索フェーズとに大きく分かれる。以下、図5のフローチャートを参照して、本実施形態のテキスト検索装置におけるインデックス作成フェーズの手順を説明する。

【0033】ステップ8301では、カウンタ1の初期 化を行なう。カウンタ1は、処理の対象となっている被 検索テキストの文書番号を示すもので、これを0に初期 化する。そしてステップ8302に移る、ステップ83 02では、カウンタ1が被検索テキストの文器数に達し たか否かを判定して、達した場合はステツブ8308に 移る。達していない場合は、ステップ8303に移る。

【0034】ステップS303では、文書番号iの被検 40 索テキストのインデックスを作成する。そしてステップ S304に移る。ステップS304では、文書番号iの 被検索テキストから、有効語候補となる文字列とその文 書内出現頻度を抽出する。そしてステップS305に移る。ステップS305に移る。ステップS305に移る。ステップS306では、文書番号iの被検索テキストに出現する有効語候補とその頻度を保存する。そしてステップS306に移る。ステップS306では、文書番号iの被検索テキストの有効語候補に関する情報により、有効語候補リストを更新する。そしてステップS307に移る。

【0035】ステップ8307では、カウンタ1の値を 1増やす。そしてステップ8302に戻る。ステップ8 308では、各有効語候補の評価値を算出する。そして ステップ8309に移る。

【0036】ステップS309では、ステップS308で求めた評価値の高いもの、例えば、評価値が所定値以上のものを有効語とし、有効語リストを作成する。そしてステップS310では、ステップS305で文書ごとに保存した有効語候補とその類度から、有効語でないものを削除し、有効語とその類度として保存する。そしてインデックス作成フェーズを終了する。

【0037】次に、図6のフローチャートを参照して、 本実施形態における検索フェーズの概要を説明する。

【0038】ステップS401では、検索キーを含む文 書を検索する。そしてステップS402に移る。ステッ アS402では、カウンタ主の初期化を行なう。カウン タ主は、ステップS401で得られた検索結果の結果番 号を示すもので、これを0に初期化する。そしてステッ 20 アS403に移る。ステップS403では、カウンタ主 が検索結果数に達したか否かを判定して、達した場合は ステップS406に移る。達していない場合はステップ S404に移る。

【0039】ステップS404では、主番目の検索結果 文書の有効語とその出現頻度を追加検索キー候補リスト に追加する。そしてステップS405に移る。ステップ S405では、カウンタ主の値を1増やす。そしてステップS403に戻る。ステップS406では、各追加検 索キー候補の評価値を算出する。そしてステップS40 7に移る。ステップS407では、ステップS406で 求めた評価値の高いものを追加検索キーとする。そして 検索フェーズを終了する。

【0040】以上に述べたように、検索対象文書から追加検索キーの候補となる有効語を抽出し、検索結果文書における有効語の出現状況を反映した追加検索キーを提示することで、検索対象文書と検索結果文書に適合した再検索が容易に行なえるテキスト検索装置を実現することができる。

【0041】 [第2実施形態] 上記第1実施形態においては、インデックス作成フェーズと検索フェーズを洞一装置で行なう場合について説明したが、これに限定されるものではない。例えば、インデックス作成フェーズだけを行なう装置であってもよい。図7はこの場合を示す本発明の第2実施形態の基本的な機能構成を示すブロック図である。

【0042】図7において、701は、被検案テキストを保持する被検索テキスト保持部である。702は、被 検索テキスト保持部701に保持されている被検索テキ ストに対して、検索を高速に行なうためのインデックス 50を作成するインデックス作成部である。703は、イン 1.7

デックス作成部702で作成したインデックスを保持するインデックス保持部である。704は有効語候補抽出部であり、被検索テキスト保持部701に保持されている被検索テキストから有効語候補を抽出し、各文書における出現頻度をカウントして有効語候補リストを作成する。705は、有効語候補頻度保持部であり、有効語候補抽出部704により抽出された有効語候補の出現頻度を文書別に保持する。

【0043】706は有効語候補リスト保持部であり、 有効語候補抽出部704により作成された有効語候補リ 10 ストを保持する。707は有効語選定部であり、有効語 候補リスト保持部706に保持された有効語候補リスト を参照して、各有効語候補の評価値を算出し、評価値の 高い有効語候補を有効語として、有効語リストを作成す る。

【0044】708は有効語リスト保持部であり、有効 語選定部707により作成された有効語リストを保持す る。709は有効語頻度作成部であり、有効語リスト保 特部708に保持された有効語リストを参照し、有効語 語候補頻度保持部705に保持された有効語候補の文書 別頻度から有効語でない語を削除して、有効語の文書別 頻度を作成する。710は有効語頻度保持部であり、有 効語頻度作成部709により作成された有効語の文書別 頻度を保持する。

【0045】インデックス保持部703に保持されたインデックスと有効語頻度保持部710に保持された有効 語の文書別頻度は、通信回線を通したり、可搬記録媒体 によって他の装置に移されて検索が行なわれる。

【0046】 [第3案施形態] 上述のようにして提供されたインデックスと有効語の文書別頻度を用いて検索を行なう装置であってもよい。 [図8はこの場合を示す本発明の第3実施形態の基本的な機能構成を示すプロック図である。

【0047】図8において、801は、図7に示す装置で作成されたインデックスを保持するインデックス保持部である。802は、検索を行なう文字列を保持する検索キー保持部である。803は検索部であり、インデックス保持部801に保持されているインデックスを用いて、検索キー保持部802に保持されている検索文字列をに一致する文字列を検索する。

【0048】804は、検索部803により検索された 検索結果を保持する検索結果保持部である。805は、 図7に示す装置で作成された有効語の文書別頻度を保持 する有効語頻度保持部である。806は追加検索キー候 補リスト作成部であり、有効語頻度保持部805に保持 された有効語の文書別頻度のうち、検索結果保持部80 4に保持された検索結果の文書に相当するものから、追 加検索キー候補リストを作成する。

【0049】807は、追加検索キー候補リスト作成部 キーのための処理を行なうよう説明しているが、これに 806により作成された追加検索キー候補リストを保持 50 限定されるものではなく、ステップS306の後にイン

する迫加検索キー候補リスト保持部である。808は追加検索キー選定部であり、追加検索キー候補リスト保持部807に保持された追加検索キー候補リストを参照して、各追加検索キー候補の評価値を算出する。809は追加検索キー保持部であり、追加検索キー選定部808により求めた評価値が高いものを追加検索キーとして保持する。

18

【0050】インデックス保持部801と有効語頻度保持部805には、上記第1実施形態の手順で作成されたインデックスと有効語頻度が、通信回線或いは可搬記録媒体等を介して提供され、保持される。

【0051】なお、本発明は図示の実施形態に限定されず種々の変形が可能である。例えば、その変形例としては次のようなものがある。

【0052】(1)上記第1実施形態では、検索結果を 絞り込むために再検索を行なうものとして、追加検索キ 一候補の評価値を求めるよう説明したが、これに限定さ れるものでなく、以下の式により評価値を求め、検索条 件を綴めて検索結果を増やすための再検索を行なう場合 の追加検索キーを提示してもよい。

【0053】

【数3】

$$E(W_i) = M \cdot (-\sum_{j=1}^M P_{i,j} \log_M P_{i,j})$$

## $P_{i,j} = rac{\dot{f X} f w}{\dot{f X} f w} f D_i$ 中における $f W_i$ の出現頻度 $f f X f w} f D_i$ 中の追加検索キー機補数

30 これは、検索結果文書に満適なく出現する語は検索キーとの関連が深く、関連する語を検索条件に加えることで関連する文書を検索できるという考えに基づいている。

【0054】(2)ユーザが再検索意図を指定することにより、上記第1実施形態と上記変形例(1)の評価値 計算法を切り替えることもできる。

【0055】(3)上記第1実施形態と上記変形例

(1)の両方の評価値計算法による追加検索キーを再検 索窓図別に提示することもできる。

【0056】(4)上記第1実施形態では、ある程度の 40 類度で出現する語を有効語や追加検索キーにするため に、評価値に出現頻度を掛けているが、出現頻度を引数 とした単調増加関数の値を掛けても良い。

【0057】(5)上記第1実施形態では、各語の出現確率のエントロピーを1から減じた値を局在度としているが、これに限定されるものではなく、他の演算により局在度を求めてもよい。

【0058】(6)上記第1実施形態では、ステップS 303でインデックス作成を行ない、その後に適加検索 キーのための処理を行なうよう説明しているが、これに 理学されるものではなく、フェーブS206の終にイン デックス作成を行なうようにしてもよい。

【0059】(7)上記第1実施形態では、必ず追加検 索キーを提示するよう説明しているが、これに限定され るものではなく、追加検索キーを提示するかしないかを ユーザが指定するようにしてもよい。

【0060】(8)上記第1実施形態では、形態素解析 により有効語候補を抽出するよう説明しているが、これ に限定されるものではなく、文字極の違いによって切り 出した文字列を有効語候補としてもよい。

語候補として抽出するよう説明しているが、これに限定 されるものではなく、他の品詞の文字列や、複合語をも 有効語候補として抽出してもよい。

【0062】(10)上記第1実施形態においては、被 検索テキスト保持部101、有効語候補頻度保持部10 5、有効語候補リスト保持部106、有効語リスト保持 部108、検索キー保持部111、検索結果保持部11 3、追加検索キー候補リスト保持部115、追加検索キ 一保持部117をRAMで、インデックス保持部10 3、有効語頻度保持部110をディスク装置で実現する 20 場合について説明したが、これに限定されるものではな く、任意の記憶媒体を用いて実現してもよい。

【0063】(11)上記第1実施形態においては、各 部を同一の計算機上で構成する場合について説明した。 が、これに限定されるものではなく、ネットワーク上に 分散した計算機や処理装置などに分かれて各部を構成し てもよい。

【0064】(12)上記第1実施形態においては、ア ログラムをROMに保持する場合について説明したが、 これに限定されるものではなく。任意の記憶媒体を用い 30 て実現してもよい。また。同様の動作をする国路で実現 してもよい。

【0065】(13)本発明は、複数の機器から構成さ れるシステムに適用しても、1つの機器からなる装置に 適用してもよい。前述した実施形態の機能を実現するソ フトウェアのプログラムコードを記録した記録媒体を、 システム或いは装置に供給し、そのシステム或いは装置 のコンピュータ(またはCPUやMPU)が記録媒体に 絡納されたプログラムコードを読み出し実行することに よっても、達成されることは言うまでもない。この場。 合、記録媒体から読み出されたプログラムコード自体が 前述した実施形態の機能を実現することになり、そのプ ログラムコードを記録した記録媒体は本発明を構成する ことになる。

【0066】(14)プログラムコードを供給するため の記録媒体としては、例えば、フロッピーディスク(登 録蕭纓)、ハードディスク、光ディスク、光磁気ディス ク、CD…ROM、CD…R、磁気テープ、不揮発性の メモリカード、ROMなどを用いることができる。

【0067】(15) コンピュータが読み出したプログ 50 すブロック圏である。

ラムコードを実行することにより、前述した実施形態の 機能が実現されるだけでなく、そのブログラムコードの 指示に基づき、コンピュータ上で稼働しているOSなど が実際の処理の一部または全部を行ない、その処理によ って前述した実施形態の機能が実現される場合も含まれ

2.0

【0068】(16)記録媒体から読み出されたプログ ラムコードが、コンピュータに挿入された機能拡張ボー ドやコンピュータに接続された機能拡張ユニットに備わ 【0061】(9)上記第1実施形態では、名詞を有効 10 るメモリに書き込まれた後、そのプログラムコ…ドの指 示に基づき、その機能拡張ボードや機能拡張ユニットに 備わるCP Uなどが実際の処理の一部または全部を行な い、その処理によって前述した実施形態の機能が実現さ れる場合も含まれることは置うまでもない。

#### [0069]

ることは善うまでもない。

【発明の効果】以上詳述したように、第1、第2及び第 4の発明であるテキスト検索装置によれば、検索対象文 書と検索結果文書に適合した再検索を容易に行なうこと が可能になる。

【0070】第5、第6及び第8の発明であるテキスト 検索方法によれば、上記第1、第2及び第4の発明と同 等の効果を奏する。

【0071】第9、第10及び第12の発明であるコン ピュータ読み取り可能な記録媒体によれば、コンピュー クによりプログラムを読み出して実行することにより上 記第1、第2及び第4の発明と同等の効果を奏する。

【0072】第3の発明である有効語頻度作成装置によ れば、テキストにおける有効語の文書別頻度を簡易かつ 的確に作成することが可能になる。

【0073】第7の発明である有効語頻度作成方法によ れば、上記第3の発明と開等の効果を奏する。

【0074】第11の発明であるコンピューク読み取り 可能な記録媒体によれば、コンピュータによりプログラ ムを読み出して実行することにより上記第3の発明と同 等の効果を奏する。

#### 【図面の簡単な説明】

【図1】本発明の第1実施形態のテキスト検索装置の機 能構成を示すプロック図である。

【図2】有効語族補リストの例を示す図である。

【図3】有効語リストの例を示す図である。

【図4】 実施形態に係るテキスト検索装置のハードウェ ア構成を示す図である。

【図5】第1実施形態におけるインデックス作成フェー ズの概要を示すフローチャートである。

【図6】第1実施形態における検索フェーズの概要を示 **すフローチャートである。** 

【図7】本発明の第2実施形態の基本的な機能構成を示 すブロック図である。

【図8】本発明の第3実施形態の基本的な機能構成を示

### 101 被検索テキスト保持部

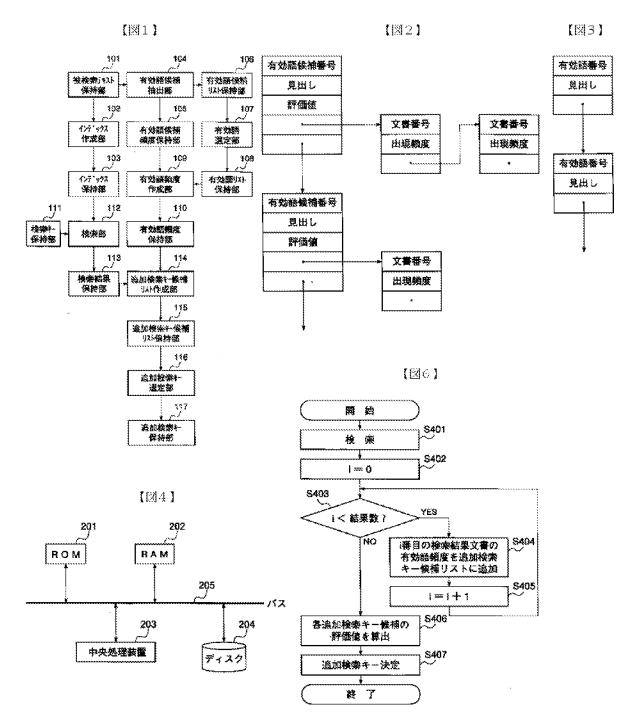
102 インデックス作成部

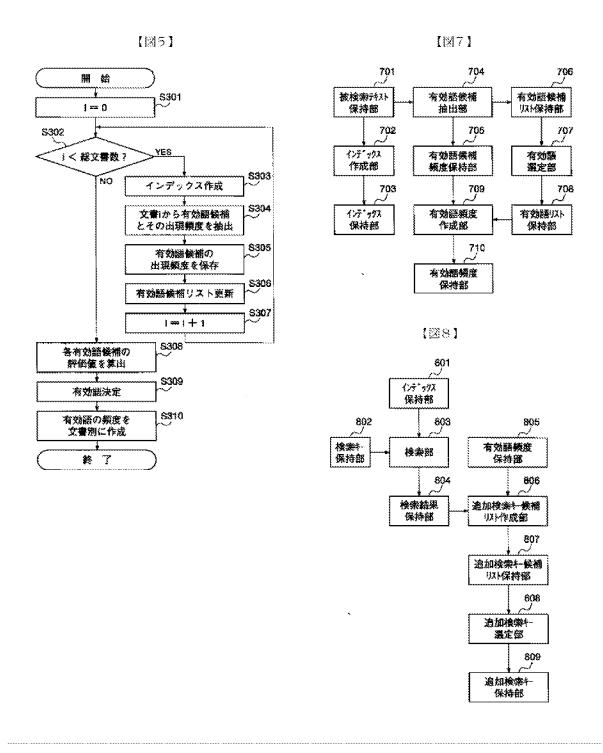
【符号の説明】

- 103 インデックス保持部
- 104 有効語候補抽出部
- 105 有効語候補頻度保持部
- 106 有効語候補リスト保持部
- 107 有効語選定部
- 108 有効語リスト保持部



- 110 有効語頻度保持部
- 111 検索キー保持部
- 112 検索部
- 113 検索結果保持部
- 114 追加検索キー候補リスト作成部
- 115 追加検索キー候補リスト保持部
- 116 追加検索キー選定部
- 117 追加検索キー保持部





フロントページの続き

#### (72)発明者 上田 隆也

東京都大田区下丸子3丁目30番2号 キヤノン株式会社内

(72)発明者 池田 裕治

東京都大田区下丸子3丁目30番2号 キヤ ノン株式会社内

F ターム(参考) 58075 ND03 NK02 NK14 NK31 PP12 PP22 PQ27 PQ38 P804